

APRENDIZAJE Y AJUSTE GENÉTICO DE SISTEMAS DIFUSOS BASADO EN LA REPRESENTACIÓN DE 2-TUPLAS LINGÜÍSTICAS

Jesús Alcalá-Fdez, Rafael Alcalá, Francisco Herrera
Departamento de Ciencias de la Computación e Inteligencia Artificial
Universidad de Granada, 18071 Granada, España
{jalcala, alcala, herrera}@decsai.ugr.es

Resumen

El Modelado Difuso Lingüístico permite la obtención de modelos claramente interpretables por el ser humano. Sin embargo, la *precisión* y la *interpretabilidad* de los modelos obtenidos son propiedades claramente contradictorias, provocando una falta de precisión en sistemas complejos. Por ello, en los últimos años se ha tratado de dotar al modelado lingüístico de una mayor precisión sin perder la interpretabilidad en un alto grado.

Siguiendo esta premisa, en este trabajo se presenta un método para la obtención de modelos lingüísticos basado en el aprendizaje evolutivo de la base de datos (granularidad y ajuste de las particiones difusas) y en el uso de un método básico para la generación de reglas. Para reducir el espacio de búsqueda y facilitar el ajuste de las funciones de pertenencia, se considera un nuevo esquema de representación de reglas basado en el modelo de 2-tuplas lingüísticas, que permite la variación lateral de las etiquetas mediante el ajuste de un único parámetro por etiqueta.

Palabras Clave: Sistemas basados en reglas difusas, modelado lingüístico, ajuste lateral, aprendizaje de la granularidad.

1 INTRODUCCIÓN

Uno de los problemas del Modelado Difuso Lingüístico (MDL) es su falta de precisión al modelar sistemas complejos. Esto se debe a que el concepto de variable lingüística impone fuertes restricciones a la estructura de regla difusa [2]. Este inconveniente aleja al MDL del deseado equilibrio entre precisión e interpretabilidad.

Para solucionar este problema, en la literatura [3], se han considerado muchas y diferentes mejoras al MDL.

Uno de los enfoques más utilizados para mejorar el comportamiento de los Sistemas Basados en Reglas Difusas (SBRDs), llamado *ajuste*, consiste en el refinamiento de la Base de Datos (BD) una vez que la Base de Reglas (BR) ha sido obtenida. Generalmente, el ajuste es una variación en la forma de las funciones de pertenencia con el principal objetivo de mejorar la precisión del modelo lingüístico. En el enfoque de ajuste clásico, si las etiquetas tienen forma triangular hay que ajustar tres parámetros por etiqueta.

En [1], se presentó un nuevo esquema de representación de reglas lingüísticas para el ajuste evolutivo de la BD mediante un desplazamiento del soporte de las funciones de pertenencia. Este enfoque se basa en el modelo de representación de 2-tuplas lingüísticas [10], que permite la variación lateral de las etiquetas mediante el ajuste de un único parámetro por etiqueta. De esta manera, se consiguieron dos objetivos:

- obtener etiquetas que contengan un conjunto de ejemplos con mejor cubrimiento (búsqueda de precisión) conservando su forma original, y
- reducir el espacio de búsqueda del proceso de ajuste respecto al ajuste clásico para obtener fácilmente un modelo óptimo.

Sin embargo, dicho esquema de aprendizaje parte de una BD inicial y una BR que permanece fija durante todo el proceso de ajuste de las funciones de pertenencia. Por lo tanto, el proceso de aprendizaje estará sesgado por la BD y BR iniciales, quedando fijos aspectos tales como la granularidad de las particiones, o el número y la estructura de las reglas obtenidas.

En este trabajo, nos proponemos extender el método de aprendizaje propuesto en [1] de manera que se puedan aprender Bases de Conocimiento (BCs) completas. Para ello, proponemos un método evolutivo para la obtención de BCs basado en el aprendizaje de la granularidad y el ajuste lateral de la BD, que aprenda al mismo tiempo el número de etiquetas por variable, el desplazamiento lateral de dichas etiquetas

(ajuste) y que, a partir de esto, mediante un método simple de generación de reglas, obtenga la BR correspondiente. A modo de ejemplo, analizaremos este enfoque en un problema real, tanto desde el punto de vista de la precisión como de la interpretabilidad.

En la siguiente Sección, se explica el modelo de representación de reglas basado en 2-tuplas. El esquema de aprendizaje seguido para el aprendizaje de BCs se introduce en la Sección 3. En la Sección 4, se presenta el método de aprendizaje propuesto en este trabajo. La Sección 5 muestra el comportamiento de dicho método en un problema de estimación real. Por último, en la Sección 6, se muestran algunas conclusiones.

2 EL AJUSTE LATERAL

En [1], se propuso un nuevo modelo de ajuste de SBRDs basado en el modelo de representación de 2-tuplas lingüísticas propuesto en [10], que permite el desplazamiento lateral del soporte de una etiqueta y mantiene la interpretabilidad asociada al modelo obtenido. Esta propuesta introduce un nuevo modelo de representación de reglas basado en el concepto de traslación simbólica.




Figura 1: Desplazamiento lateral de la etiqueta M.

La Figura 1 representa la variación lateral de la etiqueta M. La nueva etiqueta “ y_2 ” se sitúa entre B y M, siendo menor que M pero más cercana a M que a B.

La traslación simbólica de un término lingüístico es un número dentro del intervalo $[-0.5, 0.5]$ que expresa la variación del dominio de una etiqueta, cuando ésta se mueve entre las dos etiquetas laterales a la misma. Formalmente, tenemos el par

$$(s_i, \alpha_i), \quad s_i \in S, \quad \alpha_i \in [0.5, -0.5].$$

En [10], se propone tanto el modelo de representación de 2-tuplas lingüísticas, como los elementos para la comparación y agregación de información lingüística necesarios para su uso en modelos de Toma de Decisiones. A continuación, se puede ver su uso para la representación y ajuste de reglas lingüísticas considerando un modelo simple de control.

Consideremos un problema de control con dos variables de entrada, una de salida y una BD definida a partir de expertos:

$$\begin{aligned} \text{Error} &\rightarrow \{N, C, P\}, & \nabla \text{Error} &\rightarrow \{N, C, P\}, \\ \text{Potencia} &\rightarrow \{B, M, A\} . \end{aligned}$$

Regla Clásica:
R1: Si el **Errores** Cero y la **Variación del Error** es Positiva entonces la **Potencia** es Alta

Regla con Representación de 2-tuplas:
R1: Si el **Error** es (Cero, 0.3) y la **Variación del Error** es (Positiva, -0.2) entonces la **Potencias** es (Alta, -0.1)

Figura 2: Regla clásica y regla con representación de 2-tuplas.

La figura 2 muestra el concepto de regla clásica y regla con representación de 2-tuplas. Desde el punto de vista de la interpretabilidad, la regla ajustada se podría interpretar como sigue:

Si el **Error** es “*mayor* que Cero” y la **Variación del Error** es “*menor* que Positiva” entonces la **Potencia** es “un *poco menor* que Alta”.

Esta propuesta reduce la complejidad del problema de ajuste, al reducir los 3 parámetros por etiqueta a 1 parámetro de traslación simbólica.

En [1], se proponen dos enfoques para el ajuste, un enfoque global y uno local. En nuestro caso, el ajuste se produce al nivel de las particiones lingüísticas (enfoque global). En todas las reglas en las que aparece el par $(X_i, \text{etiqueta})$ se mantiene el mismo valor de ajuste. Por ejemplo, X_i es (Alto, 0.3) presentará igual valor para toda regla en la que se encontrase inicialmente el par “ X_i es Alto”.

3 APRENDIZAJE DE LA BC

Clásicamente, el aprendizaje de la BC de un SBRD se basa en la existencia de una BD previamente definida [12]. Generalmente, la BD es obtenida escogiendo un número de etiquetas para cada cada variable y fijando los parámetros mediante una distribución uniforme de dichas etiquetas. Sin embargo, mediante esta forma de trabajo, la BD tiene una gran influencia en el comportamiento del SBRD finalmente obtenido, ya que la BR obtenida depende de la bondad de la BD.

Otros enfoques realizan un *ajuste a posteriori* de la BD [1, 4, 6]. Para ello, aprenden los parámetros o la forma de las funciones de pertenencia, mejorando la precisión del SBRD. No obstante, el proceso de aprendizaje está sesgado por la BD y BR iniciales, quedando fijos aspectos tales como la granularidad de las particiones, o el número y la estructura de las reglas.

En otros trabajos se aprende conjuntamente la BD y la BR [5]. Ésto permite mejores definiciones de la BC,

pero el espacio de búsqueda que se maneja es demasiado grande haciendo muy difícil la búsqueda de una solución óptima. Otra forma de generar la BC consiste en obtener la BD y BR por separado, basándose en el aprendizaje de la BD a *priori* [9] (véase la Figura 3).

El esquema de aprendizaje considerado en este trabajo sigue este último enfoque y, se compone de dos partes con objetivos diferentes:

- Un proceso genético de aprendizaje de la BD, que permite definir:
 - El número de etiquetas de cada variable.
 - El desplazamiento lateral de dichas etiquetas.
- Un método *Ad-hoc* de generación de reglas basado en ejemplos [12], que obtiene la BR a partir de la BD previamente obtenida. Dicho método se ejecuta para cada BD generada por un Algoritmo Genético (AG), construyendo BCs completas que son evaluadas dentro de dicho algoritmo.

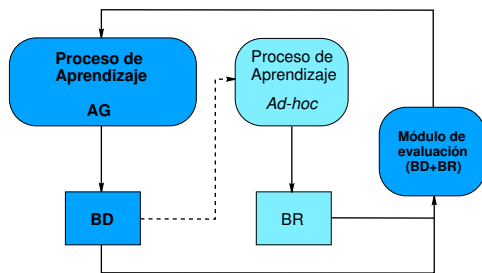


Figura 3: Esquema de aprendizaje de la BC.

4 ALGORITMO EVOLUTIVO DE APRENDIZAJE DE LA BC

Un buen esquema de evolución es el modelo genético de CHC [8]. CHC hace uso de un enfoque de “Selección basado en Poblaciones”. N padres y sus hijos son combinados para seleccionar los N mejores individuos que formarán parte de la siguiente población. En este trabajo, se aplica este método con algunas modificaciones.

El proceso de aprendizaje de la BD, se compone de dos fases (propiciadas por la población inicial y el esquema de reinicialización). En la primera, se aprende la granularidad de las particiones difusas fijando los desplazamientos a cero, mientras que en la segunda (tras la primera reinicialización), se fija la granularidad de la mejor solución y se obtienen los desplazamientos. Para ello, se utiliza un esquema de codificación doble (granularidad + desplazamientos).

En adelante, se explicarán los componentes principales del algoritmo propuesto (codificación de la BD, población inicial y reinicialización, función de evaluación y operador de cruce).

4.1 CODIFICACIÓN DE LA BD

Se utiliza un esquema de codificación doble ($C = C_1 + C_2$) para ambas partes, *granularidad* y *parámetros de traslación*:

- Aprendizaje del número de etiquetas (C_1): Es un vector de números enteros de tamaño N (siendo N el número de variables). Los posibles valores considerados son el conjunto $\{3, \dots, 9\}$:

$$C_1 = (E^1, \dots, E^N) .$$

- Ajuste de la semántica (C_2): Es un vector de tamaño $N * 9$ (N variables con un máximo de 9 etiquetas) en el que se codifican los desplazamientos de las distintas etiquetas, para cada variable. Por supuesto, si un individuo no tiene el máximo número de etiquetas posible en alguna de las variables, las zonas reservadas para los valores de esas etiquetas no se usan. De esta manera, la parte C_2 tiene la siguiente estructura:

$$C_2 = (\alpha_1^1, \dots, \alpha_{E^1}^1, \dots, \alpha_1^N, \dots, \alpha_{E^N}^N)$$

4.2 POBLACIÓN INICIAL Y REINICIALIZACIÓN

En nuestro caso, estos dos componentes están relacionados para conseguir el aprendizaje en dos fases anteriormente mencionado:

1. Primera fase (granularidad). Para ello la población inicial estará compuesta de dos bloques:
 - En el primer bloque, cada cromosoma tiene el mismo número de etiquetas para todas las variables del problema y se consideran particiones uniformes con los parámetros de traslación fijados a cero.
 - En el segundo bloque (de igual tamaño), la única diferencia es que cada variable puede tener un número de etiquetas distinto.

Puesto que CHC no tiene operador de mutación, los parámetros de traslación permanecen fijos y se aprende el número de etiquetas más prometedor para cada variable. Ésto es así hasta que se produzca la primera reinicialización.

2. Segunda fase (ajuste lateral). Para salir de óptimos locales, se utiliza un mecanismo de reinicialización [8]. En este caso, todos los cromosomas

fijan su parte C_1 a la de la mejor solución global y los parámetros de la parte C_2 se generan aleatoriamente en el intervalo $[-0.5, 0.5)$. Además, si la mejor solución global ha cambiado desde la última inicialización, ésta se incluye en la población (la explotación sigue mientras haya convergencia).

4.3 FUNCIÓN DE EVALUACIÓN

Para evaluar un cromosoma se aplica el algoritmo de generación de reglas de Wang y Mendel [12] sobre la BD codificada en dicho cromosoma. Una vez obtenida la BC completa, se calcula su Error Cuadrático Medio (ECM) y se trata de minimizar la siguiente función:

$$F_C = w_1 \cdot ECM + w_2 \cdot NR,$$

donde, NR es el número de reglas de la BC actual (para penalizar un número excesivo de reglas), $w_1 = 1$ y w_2 se calcula a partir del ECM y el número de reglas de la BC obtenida a partir de una BD con el máximo número de etiquetas permitido (9 etiquetas),

$$w_2 = \alpha \cdot \frac{ECM_{max-et}}{NR_{max-et}}.$$

Por otro lado, para considerar la existencia de ejemplos no cubiertos en el cálculo del ECM, se aplica el siguiente mecanismo:

1. Se busca la regla más cercana al ejemplo no cubierto (distancia euclídea normalizada). Las coordenadas no cubiertas del ejemplo toman como valor el centro de la correspondiente etiqueta.
2. Se busca la segunda regla más cercana. Si los consecuentes de ambas reglas se solapan sólo se dispara la regla más cercana. En otro caso, la salida debería ser por interpolación de ambas reglas. Para ello, las coordenadas del ejemplo que en un inicio estaban cubiertas, se desplazan hacia la segunda regla sin salirse del cubrimiento de la más cercana (se acercan al extremo un 10% del tamaño del soporte). Finalmente, se infiere con el nuevo ejemplo.

4.4 OPERADOR DE CRUCE

Se aplican dos operadores de cruce distintos según la información de los padres: Cuando los padres tienen distinto número de etiquetas en alguna variable, se fija un punto de corte en C_1 y se aplica el operador clásico de cruce en las dos partes C_1 y C_2 (exploración); Cuando los padres tienen igual número de etiquetas para cada variable, se aplica un operador de cruce del tipo de entorno alrededor de los padres basado en el BLX, el operador PBLX [11], sólo sobre la parte C_2 (explotación).

5 EXPERIMENTOS Y ANÁLISIS DE RESULTADOS

Con objeto de analizar el comportamiento del método propuesto, aprendizaje de la granularidad y ajuste lateral global, hemos escogido un problema real, la estimación de la longitud de las líneas de baja tensión de una compañía eléctrica [7]. En la siguiente subsección se puede encontrar una breve descripción de este problema.

Tabla 1: Métodos considerados en los experimentos.

Ref.	Método	Tipo Aprendizaje/Ajuste
[12]	WM	<i>Ad-hoc</i> Basado en Ejemplos
[6]	T	Parámetros (Ajuste Clásico)
[4]	PAL	Parámetros + Dominios + Modificadores Lingüísticos
[1]	GL	Ajuste Lateral Global
—	GGL	Granularidad + Ajuste Lateral Global + BR

La Tabla 1 presenta una breve descripción de los métodos estudiados. El método de WM es utilizado como método simple para la generación de una BC inicial. Los distintos métodos de ajuste (T, PAL y GL) son aplicados una vez que dicha BC es obtenida. El método propuesto (GGL) incluye el algoritmo de WM dentro del propio proceso de aprendizaje de la BD. T representa un algoritmo clásico de ajuste de los parámetros de las funciones de pertenencia. El método PAL ha sido comparado con métodos de ajuste de parámetros, de dominio (factores de escala) y de modificadores lingüísticos y con cualquier combinación de ellos dos a dos, y obtiene mejores resultados [4]. Por ello, sólo consideramos la combinación de los tres componentes (parámetros, dominio y modificadores) en este estudio.

Las particiones lingüísticas consideradas tendrán *cinco términos lingüísticos* con forma triangular para WM y los métodos T, PAL y GL (número con el que presentan el mejor comportamiento). Se utiliza el *centro de gravedad ponderado por el grado de emparejamiento* como operador de defuzzificación y la *t-norma del mínimo* como operador de implicación y conjunción.

Los valores de los parámetros utilizados en todos los experimentos presentados son: 50 individuos en la población, 50000 evaluaciones y 0,6 como probabilidad de cruce, para un PBLX en el caso de GL y GGL (0,2 como probabilidad de mutación por cromosoma y 0,35 para el factor a del operador de cruce max-min-aritmético para T y PAL). El factor α para la función de evaluación en GGL se ha fijado a 1,15.

Tabla 2: Resultados obtenidos por los métodos estudiados

Método	#R	ECM _{ent}	σ_{ent}	t-test	ECM _{test}	σ_{test}	t-test
WM	12.4	234712	32073	–	242147	24473	–
WM + T	12.4	158662	6495	–	221613	29986	–
WM + PAL	12.4	141638	4722	*	189279	22022	–
WM + GL	12.4	166674	11480	–	189216	14743	–
GGL	8.8	162295	4059	–	177507	16234	*

5.1 DESCRIPCIÓN DEL PROBLEMA

Algunas veces existe la necesidad de medir la longitud de las líneas de electricidad que tiene una compañía eléctrica. Esta medida puede ser útil para estimar los costes de mantenimiento de la red, lo cual constituyó el principal objetivo planteado en la provincia de Asturias [7]. La línea de baja tensión resulta costosa de medir en lugares montañosos e irregulares y, una compañía puede servir a más de 10.000 pequeños núcleos. En consecuencia, es necesario determinar un modelo indirecto para calcular la longitud de dichas líneas. De esta manera, el problema consiste en encontrar un modelo que relacione la *longitud total de línea de baja tensión* instalada en un núcleo rural con el *número de habitantes* y su *radio* [7].

Para ello, se cuenta con una muestra de 495 núcleos rurales. En los distintos experimentos, se trabaja con un modelo de *validación cruzada con 5 particiones* de datos, esto es, 5 particiones aleatorias al 20%, y la combinación de cuatro particiones (80%) como entrenamiento y una partición como test. Así se tienen 5 particiones al 80% y 20% en entrenamiento y test.

5.2 RESULTADOS Y ANÁLISIS

Para cada partición, todos los modelos evolutivos se ejecutan 6 veces, y se muestran los resultados medios del error para las 30 ejecuciones de cada algoritmo sobre cada problema. Los resultados obtenidos se muestran en la Tabla 2, donde #R representa el número de reglas, ECM_{ent} y ECM_{test} el error medio en entrenamiento y test, σ la desviación típica y t-test los resultados de aplicar un *test t-student (con 95% de confianza)* al mejor resultado medio de la correspondiente columna comparado 1 a 1 con el resto de resultados medios. La interpretación de esta última columna es la siguiente:

*	Indica el resultado con la mejor media
–	Indica peor comportamiento que el mejor

Analizando los resultados presentados en la Tabla 2 podemos indicar las siguientes conclusiones:

- A pesar de que el método puede obtener particiones con una granularidad alta, la base de reglas está aprendida mediante un método de generación de pocas reglas (8,8 sobre 81 posibles si la partición de entrada es de 9x9) que junto con el objetivo de minimizar el número de reglas facilitan la obtención de modelos precisos pero a la vez compactos y, por lo tanto, más interpretables. En este caso se han eliminado casi 4 reglas respecto a los modelos obtenidos por el resto de los métodos (reducción de un 29% en el número de reglas).
- El método propuesto muestra una fuerte reducción del error cuadrático en el conjunto de test en un problema fuertemente no lineal y con puntos de ruido, presentándose robusto frente al sobreaprendizaje y manteniendo un error en entrenamiento similar al del resto de métodos (excepto en el caso de WM+PAL). Además, la desviación típica es de las más bajas. En este caso, hay que destacar que cada partición de datos se comporta como un problema distinto, siendo la desviación en test similar a la de entrenamiento si se calculase respecto a cada partición.
- El ajuste lateral de funciones de pertenencia (un único parámetro por función) reduce el espacio de búsqueda respecto a un ajuste clásico y, por tanto, es ideal para ser combinado con el aprendizaje de la granularidad de las particiones difusas, problema en que se maneja un espacio de búsqueda de gran tamaño. Además, los modelos así obtenidos son altamente interpretables puesto que la forma de las etiquetas originales no es alterada.

Las Figuras 4 y 5 muestran la BD evolucionada y la BR obtenida con el método GGL de una de las 30 ejecuciones realizadas. Para facilitar la representación gráfica, en estas figuras las etiquetas se nombran desde '11' hasta ' $1E^i$ '. No obstante, dichas etiquetas tienen asociado un significado lingüístico impuesto por un experto. Por ejemplo, si la etiqueta '11' en la variable 'X1' significa 'BAJO', '11+0,11' se puede interpretar como 'un poco mayor que BAJO' (según la apreciación

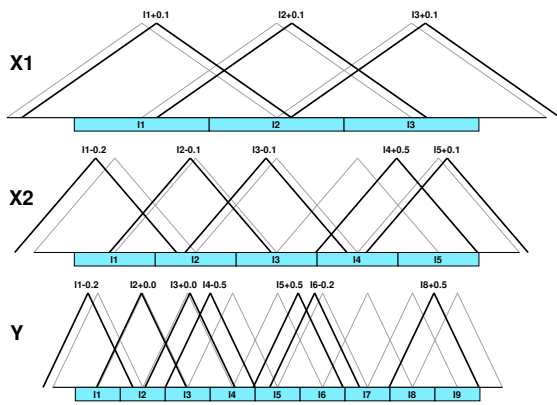


Figura 4: BD sin ajuste (en gris) y BD ajustada (en negro – sólo se muestran las etiquetas utilizadas en la BR) de un modelo obtenido con GGL.

	X1	X2	Y
#R: 10	I1+0,11	I1 -0,24	I1 -0,22
ECM-ent: 167084,468	I1+0,11	I2 -0,07	I2 -0,03
ECM-pru: 152948,173	I1+0,11	I3 -0,13	I4 -0,50
	I1+0,11	I4+0,48	I3+0,05
	I1+0,11	I5+0,11	I5+0,46
	I2+0,11	I2 -0,07	I3+0,05
	I2+0,11	I3 -0,13	I6 -0,18
	I2+0,11	I4+0,48	I6 -0,18
	I3+0,10	I2 -0,07	I4 -0,50
	I3+0,10	I3 -0,13	I8+0,48

Figura 5: BR y desplazamientos de un modelo obtenido con GGL.

del experto) ó, como en el caso del ajuste clásico, mantener el significado original de dicha etiqueta.

6 CONCLUSIONES

En este trabajo, se presenta un nuevo método para el aprendizaje de BCs basado en el aprendizaje evolutivo de la BD (granularidad y pámetros de traslación). A continuación se presentan algunas conclusiones:

- El esquema de aprendizaje seguido y el uso del ajuste lateral permiten una reducción del espacio de búsqueda que facilita la obtención de modelos precisos y compactos.
- Al seguir un enfoque global y mantener la forma de las etiquetas originales, la interpretabilidad de los modelos se mantiene en un alto grado.

En este momento, se está realizando un estudio sobre distintos problemas para determinar la dependencia entre la complejidad del problema y el funcionamiento de los distintos métodos de aprendizaje.

Agradecimientos

Este trabajo ha sido financiado por el CICYT bajo el proyecto KEEL (TIC-2002-04036-C05-01).

Referencias

- [1] R. Alcalá, F. Herrera. Genetic tuning on fuzzy systems based on the linguistic 2-tuples representation. *Procs. of FUZZ-IEEE Int. Conf.*, 2004, por aparecer.
- [2] A. Bastian. How to handle the flexibility of linguistic variables with applications. *Int. J. of Uncertainty, Fuzziness and Knowledge-Based Systems* 3:4, Pág.463-484, 1994.
- [3] J. Casillas, O. Cordón, F. Herrera, L. Magdalena (Eds). Accuracy improvements in linguistic fuzzy modeling. *Springer-Verlag*, 2003.
- [4] J. Casillas, O. Cordón, M.J. del Jesús, F. Herrera. Genetic tuning of fuzzy rule deep structures preserving interpretability for linguistic modeling. *IEEE Trans. on Fuzzy Systems*, 2004, por aparecer.
- [5] B. Carse, T.C. Fogarty, A. Munro, Evolving fuzzy rule based controllers using genetic algorithms. *Fuzzy Sets and Systems* 80, Pág.273-293, 1996.
- [6] O. Cordón, F. Herrera. A three-stage evolutionary process for learning descriptive and approximate fuzzy logic controller knowledge bases from examples. *Int. J. of Approximate Reasoning* 17:4, Pág.369-407, 1997.
- [7] O. Cordón, F. Herrera, L. Sánchez. Solving electrical distribution problems using hybrid evolutionary data analysis techniques. *Applied Intelligence* 10, Pág.5-24, 1999.
- [8] L.J. Eshelman. The CHC adaptive search algorithm: How to have safe search when engaging in nontraditional genetic recombination. *Foundations of genetic Algorithms* 1, G.J.E. Rawlin (Ed). Morgan Kaufman, Pág.265-283, 1991.
- [9] B. Filipic, D. Juricic, A genetic algorithm to support learning fuzzy control rules from examples. *Genetic Algorithms and Soft Computing*, F. Herrera, J.L. Verdegay (Eds). Physica-Verlag, Pág.403-418, 1996.
- [10] F. Herrera, L. Martínez. A 2-tuple fuzzy linguistic representation model for computing with words. *IEEE Trans. Fuzzy Systems* 8:6, Pág.746-752, 2000.
- [11] F. Herrera, M. Lozano, A.M. Sánchez. A taxonomy for the crossover operator for real-coded genetic algorithms: An experimental study. *Int. J. of Intelligent Systems* 18, Pág.309-338, 2003.
- [12] L.X. Wang, J.M. Mendel. Generating fuzzy rules by learning from examples. *IEEE Trans. on Systems, Man, and Cybernetics* 22:6, Pág.1414-1427, 1992.

Actas del

**XII CONGRESO ESPAÑOL SOBRE
TECNOLOGÍAS Y LÓGICA FUZZY**

Jaén, 15-17 de septiembre de 2004



**ESTYLF
2004**

Organizado por:

Dpto. de Informática, Universidad de Jaén

Dpto. de Ingeniería Electrónica, de Telecomunicación y Automática, Universidad de Jaén

European Society for Fuzzy Logic and Technology (EUSFLAT)

Editado por:

M^a José del Jesus Díaz
Manuel Ángel Gadeo Martos
Sebastián García Galán
Pedro González García
Luis Martínez López
Francisco Mata Mata

Impreso en España por:

Imprenta ADemanda

ISBN: 84-609-2160-3

D.L.: J-372-2004

13	<i>Sistema De Soporte De Decisiones: Aplicación A La Gestión De La Contaminación En La Ciudad De Santiago De Chile</i>	285
	M. Delgado, D. Sánchez, S. Zapata.	

TEORÍA IV

on	<i>Rationality And Congruence Axioms For Fuzzy Choice Functions</i>	291
or	I. Georgescu	

19	<i>Algunas Propiedades Algebraicas De Los Conjuntos Borrosos Intuicionistas</i>	297
25	E. Castiñeira, S. Cubillo	

Los	<i>Utilización De Reglas De Asociación En La Teoría De Conceptos L-Fuzzy</i>	303
231	A. Burusco, R. Fuentes-González, C. Alcalde	

SOFT COMPUTING PARA LA RECUPERACIÓN DE INFORMACIÓN EN INTERNET I

237	<i>A New Linguistic Modelling Of The Symmetrical Threshold Semantics</i>	309
	E. Herrera-Viedma, A.G. Lopez-Herrera, L. Hidalgo	

243	<i>Desambiguación De Sentidos En GUMSE Basada En El Refinamiento Del Sentido</i>	315
	J. de la Mata, J.A. Olivas, J. Serrano-Guerrero	

249	<i>Modelos Borrosos Para El Filtrado De Contenidos Web Basado En Usabilidad</i>	321
	E. Garcia, M. A. Sicilia, T. Calvo, J. Lázaro, D. Palomar	

255	<i>Relevancia De La Recuperación De Información En Internet Para El Soft Computing</i>	327
	A. Sobrino	

MODELADO DIFUSO I

261	<i>Aprendizaje Y Ajuste Genético De Sistemas Difusos Basado En La Representación De 2-tuplas Lingüísticas</i>	333
s.267	J. Alcalá-Fdez., R. Alcalá, F. Herrera	

	<i>METHOD: Un Enfoque Constructivo Para Modelado Difuso Híbrido</i>	339
	M. Valdés, A.F. Gómez-Skameta, J.A. Botía	

273	<i>Parámetros De Control "Dinámicos" En Un Algoritmo Genético</i>	345
	J.A. Fernández, J.R. Velasco	

279	<i>Extracción De Reglas DNF Difusas En Un Problema De Marketing</i>	351
	M.J. Del Jesus, P. González, F. Herrera, M. Mesonero	